Configurer DCPMM dans VMware ESXi pour le mode AppDirect

Contenu

Introduction Conditions préalables Conditions requises Components Used Informations générales Configuration Configurer le profil de service Vérifier ESXi Configurer NVDIMM de machine virtuelle Configurer l'espace de noms dans la machine virtuelle Dépannage Informations connexes

Introduction

Ce document décrit le processus de configuration d'ESXi sur les serveurs de la gamme UCS B à l'aide de la mémoire persistante Intel® Optane™ (PMEM) en mode géré par l'hôte.

Conditions préalables

Conditions requises

Cisco vous recommande de prendre connaissance des rubriques suivantes :

- Gamme UCS B
- Concepts du module DCPMM (Data Center Persistent Memory Module) Intel® Optane™
- Administration VMware ESXi et vCenter Server

Assurez-vous que vous répondez à ces exigences avant d'essayer cette configuration :

- Reportez-vous aux directives PMEM du guide de spécification B200/B480 M5.
- Assurez-vous que le processeur est un processeur Intel[®] Xeon[®] évolutif de deuxième génération.
- Le rapport PMEM/DRAM (Dynamic Random Access Memory) répond aux exigences de la <u>Ko</u> <u>67645</u>.
- ESXi est 6,7 U2 + Express Patch 10 (ESXi670-201906002) ou ultérieur. Les versions antérieures à la version 6.7 ne sont pas prises en charge.
- UCS Manager et Server sont dans une version 4.0(4) ou supérieure. Pour la dernière version recommandée, veuillez consulter le site <u>www.software.cisco.com/</u>.

Les informations contenues dans ce document sont basées sur les versions de matériel et de logiciel suivantes :

- UCS B480 M5
- UCS Manager 4.1(2b)

The information in this document was created from the devices in a specific lab environment. All of the devices used in this document started with a cleared (default) configuration. Si votre réseau est en ligne, assurez-vous de bien comprendre l'incidence possible des commandes.

Informations générales

Dans les serveurs UCS configurés pour le mode App Direct, les machines virtuelles VMware ESXi accèdent aux modules de mémoire NVDIMM (Non-Volatile Dual In-Line Memory Modules) DCPMM Optane.

Intel Optane DCPMM peut être configuré par l'intermédiaire de l'utilitaire de gestion IPMCTL via le shell Unified Extensible Firmware Interface (UEFI) ou via les utilitaires du système d'exploitation. Cet outil est conçu pour effectuer certaines des actions suivantes :

- Découverte et gestion des modules
- Mise à jour et configuration du micrologiciel du module
- Intégrité du moniteur
- Provisionner et configurer les espaces de noms, de région et d'objectif
- Déboguer et dépanner PMEM

UCS peut être configuré à l'aide d'une stratégie de mémoire persistante associée au profil de service pour faciliter l'utilisation.

L'utilitaire NDCTL (Non-Volatile Device Control) open source est utilisé pour gérer le soussystème de noyau Linux LIBNVDIMM. L'utilitaire NDCTL permet à un système de provisionner et d'effectuer des configurations en tant que régions et espaces de noms pour l'utilisation du système d'exploitation.

La mémoire persistante ajoutée à un hôte ESXi est détectée par l'hôte, formatée et montée en tant que data store PMem local. Afin d'utiliser le PMEM, ESXi utilise le format de système de fichiers VMFS (Virtual Machine Flying System)-L et un seul data store PMEM local par hôte est pris en charge.

Contrairement aux autres data stores, le data store PMEM ne prend pas en charge les tâches en tant que data stores traditionnels. Le répertoire d'accueil de la VM contenant les fichiers vmx et vmware.log ne peut pas être placé sur le data store PMEM.

PMEM peut être présenté à une machine virtuelle selon deux modes différents : Mode d'accès direct et mode disque virtuel.

Mode d'accès direct

Les machines virtuelles peuvent être configurées pour ce mode en présentant la région PMEM sous la forme d'une NVDIMM. Le système d'exploitation de la VM doit être sensible à PMem pour utiliser ce mode. Les données stockées sur les modules NVDIMM peuvent persister pendant les cycles d'alimentation, car la mémoire NVDIMM agit comme une mémoire adressable par octet. Les barrettes NVDIMM sont automatiquement stockées dans le datastore PMem créé par l'ESXi lors de la formation du PMEM.

Mode disque virtuel

Destiné aux systèmes d'exploitation traditionnels et hérités résidant sur la machine virtuelle afin de prendre en charge toutes les versions matérielles. Le système d'exploitation de la VM n'est pas nécessaire pour prendre en charge PMEM. Dans ce mode, un disque virtuel SCSI (Small Computer System Interface) traditionnel peut être créé et utilisé par le système d'exploitation de la machine virtuelle.

Ce document décrit la configuration pour utiliser une machine virtuelle en mode Accès direct.

Configuration

Cette procédure décrit comment configurer ESXi sur des serveurs lames UCS utilisant Intel Optane DCPMM.

Configurer le profil de service

1. Dans l'interface utilisateur graphique d'UCS Manager, accédez à **Serveurs > Stratégie de mémoire persistante** et cliquez sur **Ajouter** comme indiqué dans l'image.

reate Pe	ate Persistent Memory Policy					
roperties						
Name :	My_PMEM_Policy					
Ascription :						
General	Security					
Goals						
T ₂ Advanced	i Filter + Export - 🖶 Print		٥			
Socket Id	Memory Mode (%)	Persistent Memory Type				
	No data available					
	/					
	⊕ Add © Delete 0 /	Modify				

2. Créez **Objectif**, assurez-vous que le **mode Mémoire** est égal à 0 % comme indiqué dans l'image.

roperties		
Socket ID	: All Sockets	
Memory Mode (%)	: 0	
Persistent Memory Ty	pe : App Direct O App Direct Non Interleaved	1

3. Ajoutez la stratégie PMEM au profil de service souhaité.

Accédez à Service Profile > Policies > Persistent Memory Policy et joignez la stratégie créée.

4. Vérifiez l'état de santé de la région.

Accédez à **Serveur** sélectionné **> Inventaire > Mémoire persistante > Régions**. Le type AppDirect est visible. Cette méthode crée une région par socket de processeur.

General	Inventory	Virtual Ma	chines In	stalled Firmware	CIN	C Sessions	SEL Loga	VF Patts	Health	Degraatica	Fm) 3
Cand CIMC	CPUs	GPUs	Memory	Adapters	HBAs	NICS	ISC9 vNICs	Security	Storage	Persistent Mar	nory >>
DMMS OF	ontiguration	Regions	Nomespe	ce							
Ty-Advanced Fills	r + Doort	⊕ Print									0
ы	Socket Id		Local DIMM SI	et. DIMM Lo	cator kba	Туре	Ton	d Capacity (Free Cape	city (Status:
1	Socket 1		Not Applicable	DIMNALAS	2.DMM.	AppOinter	928		928	Hoatth	¥.
2	Socket 2		Not Applicable	DMM_G	2,00/M_	AppOinted	928		928	Health	r.
3	Socket 3		Not Applicable	DIMM_N	2.DNM.	AppOinter	928		928	Hoatth	r.
4	Socket 4		Not Applicable	DMM_U	DNM.	AppOinted	928		928	Health	v .

Vérifier ESXi

1. Dans la console Web, l'hôte affiche le nombre total de modules PMEM disponibles.

T Navigator	 Iocalhost.local 	Idomain	
💌 📱 Host			
Manage Monitor	1 This hos	t is being managed by	y vCenter Server. Actions may be performed autor
E 😚 Virtual Machines	Tou are	currently using ESXI i	n evaluation mode. This license will expire in 52 d
El Storage	2		
Q Networking	- Hardware		
	Manufacturer	r	Cisco Systems Inc
	Model		UC\$8-8480-M5
	+ 🖬 CPU		32 CPUs x Intel(R) Xeon(R) Gold 6234 CPU @ 3.30GHz
	Memory 1		382.66 GB
	M Persister	t Memory	3.62 TB
	Virtual fla	sh	0 B used, 0 B capacity

2. ESXi affiche un data store spécial composé de la quantité totale de PMEM, comme l'illustre l'image.

vmware [,] ESXi [,]						root@	•	Help 🕶 🝳	Search	
°∰ Navigator 🗆	Iocalhost.localdomain - Storage									
🕶 📱 Host	Datastores Adapters Device	es Persist	ent Memory							
Manage Monitor	🖀 New datastore 🗈 Increase capa	acity 💕 Reg	gister a VM 🛛 🧮	Datastore browser	C Refresh	Actions		Q Sear	ch	
> 🔂 Virtual Machines 🛛 1	Name	~ ~	Drive Type ~	Capacity ~	Provisioned ~	Free ~	Туре ~	Thin provisi \sim	Access	~
Storage 2	datastore1 (9)		Non-SSD	1.45 TB	56.9 GB	1.39 TB	VMFS6	Supported	Single	^
> 🧕 Networking 4	PMemDS-99225891-e4b3-0946-a	22f-c6ad55	Unknown	3.62 TB	21.62 GB	3.6 TB	PMEM	Not supported	Single	~
									4	titems 🦼

Configurer NVDIMM de machine virtuelle

1. Dans ESXi, les machines virtuelles accèdent à Optane DCPMM PMEM en tant que NVDIMM. Afin d'affecter une NVMDIMM à une machine virtuelle, accédez à la machine virtuelle via vCenter et accédez à **Actions > Edit Settings**, cliquez sur **ADD NEW DEVICE** et sélectionnez **NVDIMM** comme indiqué dans l'image.

ADD NEW DEVICE
CD/DVD Drive
Host USB Device
Hard Disk
RDM Disk
Existing Hard Disk
Network Adapter
SCSI Controller
USB Controller
SATA Controller
NVDIMM
NVMe Controller
Shared PCI Device
PCI Device
Serial Port

Remarque : lorsque vous créez une machine virtuelle, assurez-vous que la compatibilité du système d'exploitation correspond à la version minimale requise qui prend en charge la mémoire persistante Intel® Optane[™], sinon l'option **NVDIMM** n'apparaît pas dans les éléments sélectionnables.

2. Définissez la taille de NVDIMM comme indiqué dans l'image.

Edit Settings test nvdimm			3
Virtual Hardware VM Options			
			ADD NEW DEVICE
> CPU	1 ×		0
> Memory	2	68 ~	
New NVDIMM *	20	GB v	
V New NVDIMM Controller *			
Available persistent memory	3.6 TB		
Supported by guest	4 TB		

Configurer l'espace de noms dans la machine virtuelle

1. L'utilitaire NDCTL est utilisé pour gérer et configurer le module PMEM ou NVDIMM.

Dans l'exemple, Red Hat 8 est utilisé pour la configuration. Microsoft dispose d'applets de commande PowerShell pour la gestion de l'espace de noms de mémoire persistant.

Téléchargez l'utilitaire NDCTL à l'aide de l'outil disponible conformément à la distribution Linux

Exemple :

yum install ndctl # zypper install ndctl # apt-get install ndctl

2. Vérifiez la région NVDIMM et l'espace de noms créés par défaut par ESXi, lorsque la NVDIMM est attribuée à la machine virtuelle, vérifiez que l'espace correspond à la configuration. Assurezvous que le mode de l'espace de noms est défini sur **raw**, ce qui signifie qu'ESXi a créé l'espace de noms. Afin de vérifier, utilisez la commande :

# ndctl list -RuN	
admin@localhost:/etc	×
File Edit View Search Terminal Help	
)	
] [admin@localhost_stclt_ndctl_listBuN	
{	
"regions":[
{ · · · · · · · · · · · · · · · · · · ·	
"dev":"region0",	
"size":"20.00 GiB (21.47 GB)",	
"available size":0,	
<pre>"max available extent":0.</pre>	
"type": "pmem".	
"persistence domain": "unknown".	
"namespaces":[
1	
"dev": "namespace0.0".	
"mode": "raw",	
"size": "28 68 GiR (21 47 GR)"	
blockdau * promotion	
a a cockaev : pineino	

3. (Facultatif) Si l'espace de noms n'a pas encore été créé, vous pouvez créer un espace de noms à l'aide de la commande suivante :

ndctl create-namespace

La commande **ndcti create-namespace** crée un nouvel espace de noms en mode **fsdax** par défaut et crée un nouveau périphérique **/dev/pmem([x].[y])**. Si un espace de noms a déjà été créé, cette étape peut être ignorée.

4. Sélectionnez le mode d'accès PMEM, les modes disponibles pour la configuration sont les suivants :

• Mode Secteur :

Présente le stockage comme un périphérique de blocage rapide, ce qui est utile pour les applications héritées qui ne sont toujours pas en mesure d'utiliser la mémoire persistante.

• Mode Fsdax :

Permet aux périphériques mémoire persistants de prendre en charge l'accès direct à la mémoire NVDIMM. L'accès direct au système de fichiers nécessite l'utilisation du mode **fsdax**, afin d'activer l'utilisation du modèle de programmation d'accès direct. Ce mode permet de créer un système de fichiers au-dessus de la NVDIMM.

• Mode Devdax :

Fournit un accès brut à la mémoire persistante à l'aide d'un périphérique de caractères DAX. Les systèmes de fichiers ne peuvent pas être créés sur des périphériques utilisant le mode **devdax**.

• Mode brut :

Ce mode présente plusieurs limitations et n'est pas recommandé pour l'utilisation de la mémoire persistante.

Afin de changer le mode en mode fsdax, utilisez la commande :

ndctl create-namespace -f -e

S'il y a un **dev** déjà créé, l'espace de noms dev est utilisé pour formater et modifier le mode en **fsdax**.



Remarque : ces commandes exigent que le compte dispose de privilèges root, la commande **sudo** peut être requise.

5. Créez un répertoire et un système de fichiers.

Direct Access ou DAX est un mécanisme qui permet aux applications d'accéder directement aux supports persistants à partir du processeur (via les charges et les magasins), en contournant la pile d'E/S traditionnelle. Les systèmes de fichiers de mémoire persistante compatibles DAX incluent ext4, XFS et Windows NTFS.

>

Exemple de système de fichiers XFS créé et monté :

<u>sudo mkd</u>	ir < directory route (e.g./mnt/pme	m) > sudo mkfs.xfs < /dev/dev:	<u>ice</u> name (e.g	. pmem0)
		admin@localhost	:/etc	×	
Ello Edit	View Casech Terminal Hale				
File Edit	view Search reminal Hey				
}					
[admin@lo	ocalhost etc]\$ mkdir /mn	t/pmem			
mkdir: ca	annot create directory ',	/mnt/pmem': Po	ermission denied		
[admin@lo	ocalhost etc]\$ sudo mkdi	r /mnt/pmem			
[admin@lo	ocalhost etc]\$ sudo mkfs	.xfs /dev/pmer	m0		
meta-data	a=/dev/pmemθ	isize=512	agcount=4, agsize=1290112 blks		
		sectsz=4096	attr=2, projid32bit=1		
		crc=1	finobt=1, sparse=1, rmapbt=0		
		reflink=1			
data		bsize=4096	blocks=5160448, imaxpct=25		
		sunit=0	swidth=0 blks		
naming	=version 2	bsize=4096	ascii-ci=0, ftype=1		
log	=internal log	bsize=4096	blocks=2560, version=2		
	-	sectsz=4096	sunit=1 blks, lazy-count=1		
realtime	=none	extsz=4096	blocks=0, rtextents=0		
[admin@le	ocalhost etc]\$	_			

6. Montez le système de fichiers et vérifiez qu'il a réussi.



La machine virtuelle est prête à utiliser PMEM.

Dépannage

Il est généralement recommandé de monter ce système de fichiers compatible DAX à l'aide de l'option de montage **-o dax**, si une erreur est détectée.

[admin@localhost etc]\$ sudo mount -o dax /dev/pmem0 /mnt/pmem/ mount: /mnt/pmem: wrong fs type, bad option, bad superblock on /dev/pmem0, missi ng codepage or helper program, or other error.

La réparation du système de fichiers est exécutée pour garantir l'intégrité.

```
[admin@localhost etc]$ sudo xfs_repair /dev/pmem0
[sudo] password for admin:
Phase 1 - find and verify superblock...
Phase 2 - using internal log
        - zero log...

    scan filesystem freespace and inode maps...

    found root inode chunk

Phase 3 - for each AG...

    scan and clear agi unlinked lists...

    process known inodes and perform inode discovery...

        - agno = 0
        - agno = 1
        - agno = 2
        - agno = 3
        - process newly discovered inodes...
Phase 4 - check for duplicate blocks...
        - setting up duplicate extent list...

    check for inodes claiming duplicate blocks...

        - agno = 0
        - agno = 1
        - agno = 2
        - agno = 3
Phase 5 - rebuild AG headers and trees...

    reset superblock...

Phase 6 - check inode connectivity...

    resetting contents of realtime bitmap and summary inodes

         traversing filesystem ...
          traversal finished ...

    moving disconnected inodes to lost+found ...

Phase 7 - verify and correct link counts...
lone
[admin@localhost etc]$
```

Comme solution de contournement, le montage peut être monté sans l'option -o dax.

Note: Dans **xfsprogs** version 5.1, la valeur par défaut est de créer des systèmes de fichiers XFS avec l'option de **réflink** activée. Auparavant, elle était désactivée par défaut. Les options de **réflecteur** et de **dax** s'excluent mutuellement, ce qui provoque l'échec du montage.

«DAX et réflink ne peuvent pas être utilisés ensemble ! » l'erreur peut être vue dans **dmesg** lorsque la commande mount échoue :

admin@localhost:/etc	×
File Edit View Search Terminal Help	
<pre>log =internal log bsize=4096 blocks=2560, version=2 = sectsz=4096 sunit=1 blks, lazy-count=1 realtime =none extsz=4096 blocks=0, rtextents=0 [admin@localhost etc]\$ mount -o dax /dev/pmem0 /mnt/pmem mount: only root can use "options" option [admin@localhost etc]\$ sudo mount -o dax /dev/pmem0 /mnt/pmem/ mount: /mnt/pmem: wrong fs type, bad option, bad superblock on /dev/pmem0, miss ng codepage or helper program, or other error. [admin@localhost etc]\$ dmesg -T tail [mar nov 10 00:12:22 2020] ISO 9660 Extensions: Microsoft Joliet Level 3 [mar nov 10 01:47:35 2020] pmem0: detected capacity change from 0 to 2113719500 [mar nov 10 01:47:35 2020] NFS: bat option of the memory for the sector of the sector o</pre>	si r0 08
(mar nov 10 01:51:19 2020) XFS (pmemo): DAX enabled. warning: EXPERIMENTAL, use at your own risk	e
<pre>[mar nov 10 01:51:19 2020] XFS (pmem0): DAX and reflink cannot be used togethe [mar nov 10 01:53:06 2020] XFS (pmem0): DAX enabled. Warning: EXPERIMENTAL, use at your own risk</pre>	r! e
<pre>[mar nov 10 01:53:06 2020] XFS (pmem0): DAX and reflink cannot be used togethe [mar nov 10 01:59:29 2020] XFS (pmem0): DAX enabled. Warning: EXPERIMENTAL, use at your own risk</pre>	e e
[mar nov 10 01:59:29 2020] XFS (pmem0): DAX and reflink cannot be used togethe [admin@localhost etc]\$	r!

Pour contourner le problème, supprimez l'option -o dax.

 admin@localhost/etc
 ×

 File Edit View Search Terminal Help
 [admin@localhost etc]\$ sudo mount /dev/pmem0 /mnt/pmem/

 [admin@localhost etc]\$ // verify the mount was successful
 bash: //: Is a directory

 [admin@localhost etc]\$ df -h /mnt/pmem/
 Filesystem

 Size Used Avail Use% Mounted on
 /dev/pmem0

 /dev/pmem0
 20G 173M

 [admin@localhost etc]\$
 *

Montage avec ext4 FS.

Le système de fichiers EXT4 peut être utilisé comme alternative car il n'implémente pas la fonctionnalité de réflink mais prend en charge DAX.

[admin@localhost etc]\$ sudo mkfs.ext4 /dev/pmem0 mke2fs 1.44.3 (10-July-2018) /dev/pmem0 contains a xfs file system Proceed anyway? (y,N) y Creating filesystem with 5160448 4k blocks and 1291808 inodes Filesystem UUID: 164c6d57-0462-45a0-9b94-703719272816 Superblock backups stored on blocks: 32768, 98304, 163840, 229376, 294912, 819200, 884736, 1605632, 2654208, 4096000 Allocating group tables: done Writing inode tables: done Creating journal (32768 blocks): done Writing superblocks and filesystem accounting information: done [admin@localhost etc]\$ sudo mount /dev/pmem0 /mnt/pmem/ [admin@localhost etc]\$ df -h /mnt/pmem/ Filesystem Size Used Avail Use% Mounted on /dev/pmem0 20G 45M 19G 1% /mnt/pmem admin@localhost etc]\$

Informations connexes

- Guide de démarrage rapide : Provisionner la mémoire permanente Intel® Optane™ DC
- <u>Configuration de la mémoire permanente</u>
- <u>Utilitaires de gestion ipmctl et ndctl pour mémoire permanente Intel® Optane™</u>
- Support et documentation techniques Cisco Systems